

Primljen / Received: 22.12.2015.

Ispravljen / Corrected: 28.2.2017.

Prihvaćen / Accepted: 27.3.2017.

Dostupno online / Available online: 10.4.2017.

Utjecaj algoritama za uklanjanje depresija na simulaciju površinskog otjecanja

Autori:



Dr.sc. **Sanja Šamanović**, dipl.ing.geod.
Sveučilište u Zagrebu
Geodetski fakultet
Zavod za kartografiju i fotogrametriju
ssamanovic@geof.hr



Prof. dr. sc. **Damir Medak**, dipl.ing.geod.
Sveučilište u Zagrebu
Geodetski fakultet
Zavod za geomatiku
dmedak@geof.hr



Doc. dr. sc. **Duška Kunštek**, dipl.ing.građ.
Sveučilište u Zagrebu
Građevinski fakultet
Zavod za hidrotehniku
kduska@grad.hr

Prethodno priopćenje

Sanja Šamanović, Damir Medak, Duška Kunštek

Utjecaj algoritama za uklanjanje depresija na simulaciju površinskog otjecanja

Preduvjet za hidrološke analize je digitalni model reljefa (DMR) s uklonjenim depresijama. U radu su istražena su dva algoritma za uklanjanje depresija, metoda prokopavanja i metoda popunjavanja na tri geomorfometrijski različita područja. Ulazni podaci su digitalni modeli visina (DMV) nastali interpolacijom iz podataka fotogrametrijske izmjere u prostornoj rezoluciji 5 x 5 metara. Na osnovi geomorfometrijskih i statističkih analiza dana je preporuka za uporabu prihvatljivije metode kreiranja DMV-a bez depresija uz minimalne geomorfometrijske promjene, čime je dokazana važnost odabira ispravnog algoritma.

Ključne riječi:

DMR, DMV, interpolacija, hidrologija, uklanjanje depresija, metoda prokopavanja, metoda popunjavanja

Preliminary note

Sanja Šamanović, Damir Medak, Duška Kunštek

Influence of pit removal algorithms on surface runoff simulation

The digital terrain model (DTM) with removed pits is a precondition for hydrologic analysis. Two pit removal methods, the carving method and the filling method, are investigated in the paper for three different geomorphometric areas. The input data are digital elevation models (DEM) created by interpolation from photogrammetric surveying in the spatial resolution of 5x5 meters. A recommendation for the use of a more acceptable DEM creation method without pits, involving minimum geomorphometric changes, is given based on geomorphometric and statistical analyses. The importance of selecting a correct algorithm is proven.

Key words:

DTM, DEM, interpolation, hydrology, pit removal, carving method, filling method

Vorherige Mitteilung

Sanja Šamanović, Damir Medak, Duška Kunštek

Auswirkung von Algorithmen zur Depressionsentfernung auf Simulationen des Oberflächenabflusses

Voraussetzung für hydrologische Analysen ist ein Das Digitale Geländemodell (DGM) ohne Depressionen. In dieser Arbeit werden zwei Algorithmen zur Depressionsentfernung, die Grab- und die Auffüllmethode, auf zwei verschiedenen geomorphologischen Gebieten untersucht. Eingabeparameter sind digitale Höhenmodelle (DHM), die durch Interpolation von Daten fotogrammetrischer Messungen einer räumlichen Resolution von 5 x 5 Metern entstanden sind. Aufgrund geomorphologischer und statistischer Analysen werden Empfehlungen zur Erstellung des DEM ohne Depressionen mit minimalen geomorphologischen Anpassungen gegeben, womit das Gewicht der Wahl eines entsprechenden Algorithmus aufgezeigt wird.

Schlüsselwörter:

DMR, DEM, Interpolation, Hydrologie, Depressionsentfernung, Grabmethode, Auffüllmethode

1. Uvod

Digitalni model reljefa (DMR) osnova je svih geomorfometrijskih i hidroloških analiza. U Republici Hrvatskoj se u službenoj upotrebi koriste tri skupa podataka za DMR, i to [1]:

- izvorni podaci DMR-a nastali fotogrametrijskom restitucijom (vektorski DMR - izvorni)
- izvorni podaci DMR-a nastali digitalizacijom HOK-a (vektorski DMR - izvorni)
- digitalni model visine (DMV) rezolucije 25x25 m (ASCII DMR - izvedeni).

Geomorfometrija je znanstvena grana koja kao osnovnu podlogu u svojim istraživanjima koristi DMR, čijom analizom je omogućeno izdvajanje morfometrijskih parametara terena i površinskih značajki. Značenje DMR-a u morfometrijskim analizama je veliko, a rezultati geomorfometrijskih i hidroloških analiza izvedenih iz njega uvjetovani su karakteristikama i kvalitetom DMR-a, ali i interpolacijskom funkcijom koja se primjenjuje pri geomorfometrijskim i hidrološkim analizama. Osim toga, geomorfometrijske analize zahtijevaju znanstvenu i stručnu suradnju između struke zadužene za kreiranje digitalnog modela visina (geodezija) i drugih srodnih geoznanosti (hidrologija, geologija, šumarstvo...).

Izučavanje mogućnosti kvalifikacije i kvantifikacije problema određivanja otjecanja unutar slivnog područja kao prostorne jedinice uporabom znanja i posebnih tehnika izrade i obrade DMR-a zauzima značajno mjesto u mnogobrojnim znanstvenim i stručnim disciplinama: hidrologiji, meteorologiji, hidraulici, geologiji, pedologiji, morfologiji, te u okviru bioloških, šumarskih i agronomskih znanosti. Pragmatično značenje izučavanja pronalazi se u rješavanju vodnogospodarskih problema uređenja slivova, reguliranju i korištenju prirodnih vodotoka, uređenja bujica, te globalno u obrani od poplava urbanih i ruralnih područja [2]. Dio parametara pri kreiranju DMR-a prilagođen je potrebama korisnika (rezolucija, stupanj generalizacije...), no zajednička potreba svih subjekata uključenih u prostorne analize je izrada DMR-a, koji sa zadovoljavajućom kvalitetom predstavlja stvarni reljef. DMR je važna ulazna komponenta topografije pri modeliranju poplava, stoga napredne prostorne mikrokorekcije reljefa povećavaju točnost simulacije otjecanja i određivanja plavljenog područja [3].

Utjecaj kvalitete DMR-a na opisivanje plohe slivnog područja, kao ulaznog podatka u algoritmima za određivanje i praćenje pojava erozije i taloženja, ima presudan utjecaj na kvalitetu dobivenog rezultata [4]. Kvaliteta DMR-a je važan i nezaobilazan parametar pri svim analizama površinskog otjecanja u algoritmima praćenja erozije, taloženja, klizišta, te plavljenih područja, ekologije i širenja zagađenja vodenim putem. Indirektno ove pojave utječu na stabilnost građevinskih objekata (cestovnih, željezničkih nasipa). Osim toga, detaljno poznavanje hidrologije vodotoka i hidraulike toka može ublažiti neželjene posljedice poplava oko mosta i može biti od presudne važnosti za sigurnost ljudi [5].

U inženjerskoj praksi često se javlja potreba za što pouzdanijom procenom otjecanja sa slivova za koje ne postoje vodomjereni podaci ili postoje oni koji nisu dovoljno dobro izučeni. Osobiti problem predstavljaju mali slivovi nepravilnog oblika odakle se otjecanje ne može pouzdano proračunati na osnovu često primjenjivih jednostavnih parametarskih metoda (kao što je racionalna ili SCS metoda [6]).

Za potrebe hidrološkog definiranja otjecanja sa sliva u spomenutim uvjetima, koriste se konceptualni parametarski modeli, s ulazom - oborinom i izlazom - otjecanjem, popularno nazvani CRRS modeli ("Conceptual Rainfall - Runoff Models"). CRRS modeli se odlikuju velikim brojem klimatoloških i fizičko - geografskih parametara koji u parametarskim modelima opisuju i modificiraju opis procesa otjecanja [7]. CRRS modeli imaju veliki broj parametara koje nije moguće odrediti iz mjerenih veličina koje opisuju karakteristike sliva, te se zbog toga koristi kalibracija [8].

CRRS modeliranje je sastavljeno od relativno malog broja strukturno složenih elemenata gdje svaki od njih simulira određenu fazu procesa u slivu, odnosno određenu fazu procesa transformacije brutto i/ili efektivnu kišu u odgovarajući hidrogram otjecanja. Ključni nehidrološki ulazni element u spomenuto CRRS modeliranje je DMR prikazan kroz diskretizacijski sustav elemenata sliva kao nositelja informacije o nagibu terena, pravcu i smjeru tečenja vode, duljini prijednog puta vode koje otječe po površini sliva, vremenu tečenja te elementa spremnika kojim se simulira efekt retencije sliva.

Algoritmi za određivanje smjera površinskog otjecanja koriste se kako bi simulirali kretanje vode, od viših do nižih točaka na terenu isključivo pod utjecajem gravitacije, i u direktnoj su ovisnosti o kvaliteti i vjerodostojnosti DMR-a. Ovisno o tome da li algoritam koncentrira svu vodu u sredinu piksela ili cijeli piksel ravnomjerno prekriva, razlikujemo jednodimenzionalne algoritme u koje se ubrajaju D8, Rho8 i KRA [9-11] i dvodimenzionalne, D ∞ , FD8 i DEMON [12-14], algoritme CRRS modela površinskog otjecanja. Bilo da se radi o jednodimenzionalnim modelima površinskog otjecanja ili višedimenzionalnim, ključna pretpostavka jest da svaki analizirani piksel DMR-a ima bar jedan piksel u neposrednom susjedstvu, koji je niži od njega i prema kojem usmjerava svoje otjecanje. Ako se radi o lokalnom minimumu (depresiji), tada ovaj uvjet nije ispunjen i dolazi do numeričkih problema pri računanju površinskog otjecanja. Stoga je potrebno prije računanja površinskog otjecanja ukloniti lokalne minimume (depresije) iz DMV-a.

Površinska udubljenja (sink, pit, depression) u DMV-u tretiraju se kao smetnja u hidrološkom modeliranju. Istražujući primjenu hidroloških simulacija u modelima površinskog otjecanja, kao što su određivanje hidrografske mreže, smjera površinskog otjecanja, akumuliranja vode po terenu i izračun slivnog područja, uočeno je da se uklanjanje depresija kao pretkorak u hidrološkim analizama primjenjuje ovisno o raspoloživosti modula implementiranog u GIS programu u kojem se analize rade, a ne u ovisnosti o geomorfometriji područja. Uklanjanje depresija mijenja geomorfometriju DMR-a, što utječe na izračun

različitih geomorfometrijskih parametara ključnih za daljnje hidrološke izračune, pa je izbor metode uklanjanja depresija važan pretkorak u hidrološkim analizama.

Iako termin DMR u Hrvatskoj obuhvaća izvorni i izvedeni DMR, u daljnjem tekstu je s obzirom na pravilnu rastersku strukturu visina pohranjenih u izvedenom DMR-u za taj model korišten naziv digitalni model visina (DMV).

Preporuke za izbor prihvatljivijeg algoritma za uklanjanje depresija, uzimajući u obzir geomorfometrijske karakteristike istraživanog područja, poslužit će kao osnova za buduće projekte oslonjene na geomorfometrijska i hidrološka istraživanja, otvarajući vrata suradnji geodezije i drugih geoznanosti.

2. Algoritmi za uklanjanje depresija na DMV-u

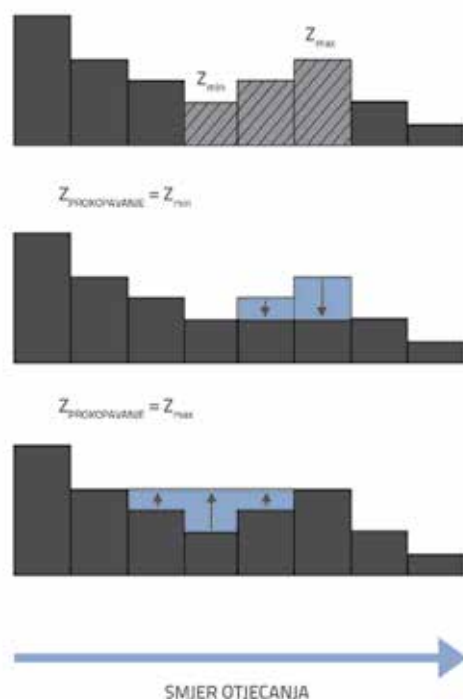
U geomorfologiji depresija je uleknina na zemljinoj površini bez obzira na postanak, oblik i veličinu. Dio je kopnene površine ili morskog dna koji se nalazi ispod razine okolnog terena zbog tektonskih pomaka, spuštanja duž rasjednih crta, epirogenetskog svijanja ili nabiranja [15]. Depresije se u DMV-u javljaju kada je piksel ili grupa piksela u potpunosti okružena susjednim pikselima veće nadmorske visine.

Neke od njih mogu biti prirodne, posebno u glacijalnom i krškom području [16], dok velika većina depresija predstavlja nepravilnosti DMV-a, i kao takva predstavljaju značajnu smetnju u hidrološkoj simulaciji i izračunima parametara tečenja (proces smanjivanja infiltracije, smanjenje i važnost skladištenja vode u depresijama na realne procese otjecanja u analiziranom prostoru, smjer tečenja, akumulacija tečenja, protok, vrijeme koncentracije i ostali hidrološki parametri). Iako je u ovom radu razmatran samo utjecaj uklanjanja depresija na proces površinskog otjecanja, uklanjanje depresija značajno utječe na vodnu bilancu sliva u cijelosti.

Prikupljanje podataka za izradu DMV-a izvodi se fotogrametrijskim kartiranjem iz aerosnimaka, laserskim skeniranjem, terestričkom izmjerom, no bez obzira na način prikupljanja podataka ili daljnju obradu, teško je na kreiranom DMV-u ustanoviti je li depresija stvarna značajka terena ili je nastala tijekom procesa obrade podataka (umjetna depresija). Umjetne depresije su često posljedica pogrešaka tijekom uzorkovanja (pogrešno klasificirani ulazni podaci) ili interpolacije, generalizacije, zaokruživanja interpolirane vrijednosti na nižu točnost, ujednačenja piksela unutar područja ili zaglađenja kao posljedice preuzorkovanja. Posebno suvremeni postupci prikupljanja podataka za DMV, kao što su: lasersko skeniranje iz zraka, odnosno metode slikovnih korelacija u digitalnoj fotogrametriji uz vrlo visoku učestalost prikupljanja podataka imaju malu selektivnost, pa pri interpolaciji DMV-a neminovno dolazi do nerealnih morfometrijskih oblika, a među njima i do pojave depresija koje u stvarnom reljefu ne postoje [17]. Pojava umjetnih depresija povezana je i s vertikalnom i horizontalnom rezolucijom izvornih podataka visina i razvedenosti reljefa. Umjetne depresije su češće u područjima male razvedenosti reljefa, što možemo pripisati ograničenoj vertikalnoj točnosti

DMV-a [18]. S druge strane, ponekad je stvarne depresije teško definirati (područje pod šumama) jer većina metoda snimanja iz zraka (RADAR, LIDAR) prikuplja podatke za kreiranje digitalnog modela površina umjesto digitalnog modela visina [19]. Kako niti jedna tehnika razlikovanja stvarnih od umjetnih depresija (osim terenskog istraživanja) ne daje sasvim pouzdane rezultate, a i postupci su složeni, unutar svih GIS programa algoritmi za uklanjanje depresija rade neselektivno. Većina stvarnih depresija u konačnici se prelijeva u nizvodni diskretizacijski piksel, pa unatoč neselektivnom uklanjanju depresija može takav ispravljen model biti točan.

Najstarija metoda za pronalaženje depresija na modelu temelji se na postupku koji se izvodi u dva koraka. U prvom koraku se pronalaze najniže točke skeniranjem modela po recima (row-by-row). U drugom koraku se za svaku točku depresije pronalaze pikseli razgraničenja (piksela gdje prestaje depresija) i točka prelijevanja (piksel s kojeg je moguće otjecanje). Postupak je iterativan, pri čemu broj iteracija ovisi o broju i složenosti depresija. Jednostavnija i učinkovitija metoda se sastoji u postupku nazvanom "od nižega prema višem" (eng. *from lower to higher*) i "od ruba prema unutra" (eng. *from edges inwards*), koji se zasniva na prioritetu podatkovne strukture poznate kao binarno nakupljanje (eng. *binary heap*) [20]. Za razliku od skeniranja po redovima, primjenom ove metode dovoljna je samo jedna pretraga kako bi se prepoznale depresije i točke prelijevanja. CRRS modeli u kojima je hidrografska mreža definirana na temelju simulacije površinskog toka GIS tehnologijom, zahtijevaju da su na DMV-u najprije uklonjene sve depresije, a uobičajena je praksa da ih se detektira i ukloni u DMV-u već na prvom proceduralnom koraku hidrološke analize.



Slika 1. Primjer metoda uklanjanja depresija

Prisutnost depresija u DMV-u sprječava simulaciju tečenja vode u površinskom toku po površini terena, kao i duž vodotoka višega i nižega reda, što uzročno-posljedično stvara nepovezane obrasce toka vode u slivu s defragmentiranom hidrografskom mrežom, te lažnim podslivnim i slivnim prostornim odrednicama (vododjelnicama). Za stvaranje homogenosti i potpune povezanosti hidrografske mreže, vodu iz svakog piksela DMV-a treba preusmjeriti prema linijama koncentriranog otjecanja, pri čemu prisutnost depresija u DMV-u stvara prekide u kontinuitetu linija otjecanja, kao i modeliranje drugih prostornih hidroloških procesa (modeliranja vremena koncentracije, računanja visine i trajanja plavljenja, modeliranja retencijskog i retardacijskog vremena sliva, erozije...). Postoje dvije osnovne metode uklanjanja depresija (slika 1.):

- metoda prokopavanja (eng. *carving or breaching*)
- metoda popunjavanja (eng. *filling*).

Iako su Soille [21] i Lindsay i Creed [22], uspoređujući korigirane DMV-ove došli do zaključka da postupak koji kombinira dvije osnovne metode najmanje utječe na izvorni DMV, većina GIS programa zbog robusnosti algoritma i dalje koristi jednostavniju metodu popunjavanja. Također, izolirane, ali duboke depresije problematične su za metodu prokopavanja [19] jer značajno mijenjaju konfiguraciju terena. Suvremene metode prikupljanja podataka kao što su LIDAR također potiču razvoj novih algoritama koji se baziraju na optimiziranim alatima za uklanjanje depresija [23].

Srivastava je [24] uspoređujući dvije metode implementirane u ArcView (popunjavanje) i TOPAZ (prokopavanje) na 30 metarskom DMV-u Valley regije u Virginiji, ustanovio da za testirano područje metoda prokopavanja na ravniča.

Istražujući depresije na modelu i uspoređujući dvije metode uklanjanja depresija na DMV-u različite rezolucije (50, 100 i 200 metara), došlo se do zaključka da veće rezolucije rezultiraju pojavom većih depresija te većim akumuliranjem vode u slivu [25]. Budući da je standardna metoda uklanjanja depresija na DMV-u (metoda popunjavanja) naišla na kritiku akademske zajednice zbog velikog utjecaja na modeliranje sustava mreže površinskog otjecanja [26], razvoj je novih algoritama u sve većem zamahu.

Metoda popunjavanja je najraširenija metoda prije svega zbog svoje jednostavnosti. U početku su algoritmi za uklanjanje depresija primjenjivali metodu popunjavanja i bili su kreirani za mala područja, niske rezolucije i zaglađeni DMV. Osnovni nedostatak te metode je značajna promjena izvornog digitalnog modela [9, 27]. Popunjavanje je postupak kojim se podiže visina depresije dok nivo ne dosegne visinu točke odakle je otjecanje moguće [28], odnosno popunjavanje raste do točke prelijevanja, a rezultat su pikseli čija je vrijednost uvijek ista ili veća od DMV-a. Postupak se ponavlja dok sve depresije nisu popunjene, ili pravilnije rečeno, dok svim pikselima nisu pridružene linije otjecanja.

Većina algoritama za popunjavanje depresija bazirana je na jednodimenzionalnim algoritmima za određivanje smjera

otjecanja [29], kod kojih svaki piksel preuzima jednu od osam vrijednosti, ovisno o tome koji je od osam susjednih piksela u smjeru najstrmijeg nagiba, pri čemu kao vrijednost piksela uzima sredinu pojedinog piksela.

Jedan od prvih algoritama razvili su Jenson i Domingue [27], stvarajući na taj način ravne površine koje omogućuju daljnje otjecanje. Postupak je računski složen i dugotrajan, a sastoji se od popunjavanja pojedinačnih piksela depresije podizanjem visine svakog piksela na najnižu susjednu visinu na rubu depresije. Svaki će piksel u ispravljenom modelu biti dio putanje monotono padajuće funkcije koja završava na rubu modela. Putanja je sastavljena od susjednih piksela u horizontalnom, vertikalnom ili dijagonalnom smjeru rasterskog grida čija vrijednost kontinuirano opada.

Postupak koji su osmislili Jenson i Trautwein [30] sličan je, ali je zbog više iteracija sporiji. Svaki piksel koji se nalazi u depresiji podiže se na najnižu vrijednost na rubu depresije, pa svaki piksel izlazne slike ima barem jedan put koji vodi preko nižih piksela do ruba depresije. Put se sastoji od piksela u susjedstvu (svih osam smjerova) koji moraju zadovoljavati uvjet stalnog smanjenja vrijednosti. Ako ulaznu površinu oduzmemo od izlazne, svaki piksel dobivene vrijednosti jednak je dubini depresije u jedinici ulazne površine.

Uklanjanje depresija metodom popunjavanja koju je razvio Mark [31] slična je ovoj metodi, ali kao međukorak pronalazi slivna područja za piksele koja nemaju susjedne piksele nižih visina. Modul identificira piksele nižih visina od najniže visine granice slivnog područja i koristi te piksele kao početnu ravninu u postupku razgraničenja sliva. U postupku generiranja slivnog područja, jedno po jedno slivno područje raste, a ravna područja se dodjeljuju prvom susjednom slivnom području.

Postupak uklanjanja depresija prema metodi koju su razvili Planchon i Darboux [32] može se podijeliti u dvije faze. Prva faza se sastoji u preplavlivanju cijelog DMV-a vodom, a u drugoj se fazi s modela odvodi višak vode. Preplavlivanje površine izvodi se pridruživanjem najvišeg nivoa vode svim pikselima DMV-a, nakon čega se iterativno ocjeđuje višak vode sa svakog piksela. Kako bi se pronašao nizvodni put za svaki piksel i potpuno ocijedio višak vode, cijeli se DMV pretražuje u svih osam smjerova. U završnoj fazi voda iz depresije drenira se na nivo najviše točke prelijevanja oblikujući liniju toka sve do granica DMV-a, što rezultira modelom s uklonjenim depresijama.

Prvi algoritam za uklanjanje depresija metodom prokopavanja kreirao je Rieger [33], a bazirao se na spuštanju piksela u okolini depresije. Kasniji algoritmi uključuju uklanjanje depresija metodom prokopavanja bazirano na duljini prokopnog kanala, pri čemu se razvija mreža koja oblikuje put otjecanja od depresije do prve susjedne niže depresije, stvarajući mrežu linija koncentriranog otjecanja. Metoda se i najčešće primjenjuje za rješavanje depresija koje nisu previše udaljene jedna od druge [34]. Polazeći od depresije algoritam ne popunjava depresiju nego prokopava teren kako bi se oblikovalo otjecanje iz depresije, tj. prokopavanjem snižava visinu piksela koji se nalaze na putu otjecanja [35] odvođeci vodu do prvog sljedećeg nižeg piksela ili do ruba modela.

Uklanjanje depresija prema Conradu bazirano je na snižavanju vrijednosti piksela kako bi se pronašao izlaz iz depresije, a sastoji se od dva koraka [36]. U prvom koraku algoritam prepoznaje put linije koncentriranog otjecanja, pri čemu područje bez depresije dobiva vrijednost nula, a zatim se depresiji pridodaje vrijednost između 0 i 8 ovisno o putu kojim će se otjecanja usmjeriti iz depresije. Drugi korak se sastoji od uklanjanja depresije korištenjem izračunane linije koncentriranog otjecanja.

Wang i Liu [37] predložili su novu učinkovitu metodu za popunjavanje depresija koja istovremeno može odrediti smjer otjecanja i prostornu podjelu slivova u jednom koraku. Oni uvode novi koncept prelijevanja iz depresija i progresivnu metodu optimalnog puta prelijevanja, baziranu na strukturi podataka prioritarnog reda i analize optimalnog puta otjecanja.

Metoda ograničenja u skoku koju su razvili Martz i Garbrecht [34] ograničava duljinu prokopavanja kanala do maksimalno dva piksela, a sve ostale depresije rješava popunjavanjem.

Pristup koji su razvili Lindsay i Creed [22] izabire popunjavanje ili otjecanje ovisno o tome koja metoda izaziva najmanje promjena na DMV-u. Optimalni pristup uklanjanju depresija razvija Soille [21] kombinirajući metodu punjenja i otjecanja kako bi se smanjile razlike u visini između izvornog DMV-a i prepravljenog. Pristup je baziran na popunjavanju do određenog nivoa, a dalje se koristi otjecanje. Nivo je postavljen tako da se smanji broj razlika u visini između izvornih podataka i prepravljenih ili da se smanji broj modificiranih piksela. Većina GIS programa unutar svojih modula ima implementiranu metodu koju su razvili Planchon i Darboux [32] ili koju su razvili Wang i Liu [37].

GRASS i IDRISI imaju implementiranu metodu popunjavanja prema Jensonu i Domingue, a Arc GIS koristi metodu koju su razvili Tarboton i drugi [38] i Hutchinson [39]. Metodu prokopavanja koriste GIS Whitebox GAT, TopoToolbox [25]. SAGA omogućava izbor između većeg broja modula za uklanjanje depresija: Planchon/Darboux, Wang/Liu, XXL Wang/Liu ili Conrad. Upravo zbog mogućnosti uspoređivanja dviju osnovnih metoda uklanjanja depresija unutar jednog GIS softvera, što kod drugih softvera nije moguće zbog implementacije samo jedne metode, za definiranje optimalne metode izabran je softver otvorenog koda SAGA. Analize su rađene metodom prokopavanja koju je razvio Conrad i metodu popunjavanja koju su razvili Planchon i Darboux.

Metoda koju su razvili Planchon i Darboux, polazeći od inicijalne površine Z , konačnu površinu W_f kreira u dva koraka [32]. U prvom koraku, osim na granicama modela, metoda navodi površinu W s beskonačnim visinama. Tijekom druge faze, visine površine W iterativno se smanjuju i u konačnici pretvaraju u površinu W_f , zadržavajući dva svojstva:

- $W_f \geq Z$
- za svaki piksel c , površine W_f , postoji put koji vodi do ruba modela i postoji nagib ϵ koji vodi od jednog piksela prema drugom (silazni put).

Kada je piksel na rubu modela, odnosno kada je $W(c) = Z(c)$, tada $W(c)$ doseže svoj minimum, pa je $W(c) = W_f(c)$. Kao posljedicu imamo da se visina piksela c više ne mijenja, izraz (1):

$$Z(c) \geq W(n) + \epsilon(c, n) \rightarrow W(c) = Z(c) \quad (1)$$

Obrnuti slučaj, izraz (2), kada je $Z(c)$ niže od $W(n)$, $W(c)$ može se opisati kao:

$$\begin{aligned} W(n) + \epsilon(c, n) \\ W(c) > W(n) + \epsilon(c, n) > Z(c) \rightarrow W(c) = W(n) + \epsilon(c, n) \end{aligned} \quad (2)$$

U sljedećem koraku radi se nova iteracija koja dovodi W do konačnog rezultata (W_f).

Olaf Conrad razvio je metodu koja polazeći od digitalnog modela visina, koristeći put otjecanja oblikuje modificirani digitalni model. Za definiranje puta otjecanja korišten je jednodimenzionalni algoritam otjecanja D8. Smjer otjecanja određuje se počevši od točke depresije preko piksela minimalne visine koji je niži od točke depresije uzimajući u obzir osam susjednih piksela [40]. Ako takav susjedni piksel ne postoji, smjer nije definiran. Vrijednosti matrice definirane su kao smjer otjecanja:

$$\begin{aligned} \text{DDIRN}(i, j) &= 2^{d-1} \text{ za } d = 1, 2, \dots, 8, \text{ gdje je } d \text{ smjer otjecanja} \\ \text{DDIRN}(i, j) &= 0 \text{ za nedefinirani smjer} \end{aligned}$$

Iako ovaj princip omogućava definiranje višestrukih smjerova otjecanja iz depresije, u konačnici je dopušten samo jedan smjer. Kako bi se kompenziralo povećanje puta u dijagonalnom smjeru, vrijednost visine susjednog piksela je definirana faktorom $1/\sqrt{2}$. Na taj način reducira se pojava susjednih piksela jednake vrijednosti. U slučaju piksela jednakih vrijednosti izabire se prvi piksel u smjeru kazaljke na satu počevši iz smjera sjevera.

Procedura uklanjanja depresija započinje definiranjem piksela depresije. Točka prelijevanja, izraz (3), definirana je kao točka na rubu depresije s najnižom visinskom razlikom od depresije. Ako se pretpostavi da je

$$N(i, j) = \{(i-1, j-1), (i-1, j), (i-1, j+1), (i, j-1), (i, j+1), (i+1, j-1), (i+1, j), (i+1, j+1)\} \quad (3)$$

osam susjednih piksela točke prelijevanja (i, j) , a

$$\begin{aligned} A(p, q) &= \{(i, j) \mid (\text{DBASN}(i, j) = \text{DBASN}(p, q)) \wedge \\ &((k, l) \mid (\text{DBASN}(k, l) \neq \text{DBASN}(i, j))) \wedge \\ &((k, l) \in N(i, j)))\} \end{aligned} \quad (4)$$

tada je skup točaka na granici depresije (p, q) . Točka prelijevanja (i, j) područja prelijevanja $A(p, q)$ definirana je izrazom (5):

$$(i, j) = ((k, l) \mid \min(\text{ELDIF}((k, l), (p, q)) \forall ((k, l) \in A(p, q))) \quad (5)$$

gdje ELDIF izračunava razliku visina između točaka.

Pregledavanjem graničnih točaka područje se povećava, a postupak se prekida kada se obrade sve točke depresije i pronađe

točka prelijevanja. Kada je definirana točka prelijevanja, smjerovi otjecanja se modificiraju kako bi usmjerili otjecanje prema njoj. Smjer otjecanja od točke prelijevanja definira se kao smjer prema točki prelijevanja susjedne depresije koja ima najnižu visinu.

Glavna razlika dviju metoda u hidrološkom smislu je u tome što algoritam prokopavanja računa trajektoriju tečenja i forsira je bez obzira na broj piksela ulaznog uzorka terena, a algoritam popunjavanje depresija povećava razinu piksela (mijenja njihovu visinu) područja dok njihov broj kao ulazni signal ostaje isti. To upućuje na zaključak da je, osim jednodimenzionalnih signala, prokopavanje više selektivan algoritam i da je prikladniji za definiranje trajektorija tečenja po terenu.

3. Područje istraživanja i podaci

Ulazni podaci za testiranje dva algoritma za uklanjanja depresija uključuju DMV rezolucije 5x5 metara na tri geomorfometrijski različita područja Republike Hrvatske (planinski masiv Biokovo, planina Papuk i ravničarsko područja istočne Hrvatske unutar općine Nijemci) (slika 2. i 3.).



Slika 2. Karta Republike Hrvatske s naznačenim lokacijama istraživanja

Podaci za analizu, aerofotogrametrijske snimke u mjerilu 1:20 000 (Cikličko snimanje "Dubrovnik i okolica", 2005., "Zapadna Slavonija", 2001. i "Istočna Slavonija", 2002.), parametri vanjske orijentacije i podaci o kamerama dobiveni su od Državne geodetske uprave. Svi modeli obrađivani su u softveru MATCH-T s istim parametrima. Budući da su ulazni podaci (aerofotogrametrijske snimke) iz različitih cikličkih snimanja snimljeni različitim kamerama, snimke Papuka i Nijemaca su crno-bijele, a Biokova u boji. Sve su skenirane istom rezolucijom (21 μ m) i na istom skeneru (Intergraph, PhotoScan TD). Stereoskopskom metodom prikupljeni su podaci (točke na površini terena) u pravilnom razmaku poluautomatskim metodama, te su dopunjeni linijama vododjelnicama cjelokupnog sliva i podslivova manualnim metodama. Rasteri visinskih točaka (digitalni modeli visina) koji su korišteni za daljnje analize dobiveni su metodom interpolacije.

Interpolacija je postupak kojim se pronalazi vrijednost funkcije između dviju poznatih vrijednosti [41].

Ploha zadana pravilnom ili nepravilnom razdiobom točaka određuje se kako slijedi:

Neka su dane točke (x_i, y_i, z_i) za $i=1, 2, \dots, n$, raspoređene po nekoj površini. Traži se funkcija $z=f(x, y)$ koja na danim točkama poprima zadane vrijednosti, a na svim ostalim točkama (x, y) poprima smislene vrijednosti unutar zadanog područja [42]. Podaci su prikupljeni kombiniranjem tri metode interpolacije: linearne, metode najmanjih kvadrata i metode konačnih elemenata. Osnovna je ideja linearne metode interpolacije ta da se umjesto jednog polinoma visokog stupnja koristi više polinoma prvog stupnja [43]. Na svakom podintervalu $[x_{k-1}, x_k]$, polinom p_k (6) je jedinstveno određen, a zapisujemo ga relativno s obzirom na početnu točku intervala:

$$p_k(x) = c_{0,k} + c_{1,k}(x - x_{k-1}) \text{ za } x \in [x_{k-1}, x_k], k=1, \dots, n \quad (6)$$

Interpolacijski polinom (7) možemo zapisati kao:

$$p_k(x) = f[x_{k-1}] + f[x_{k-1}, x_k] * (x - x_{k-1}) \quad (7)$$



Slika 3. Obrađivano područje Biokovo, Papuk i Nijemci

pa slijede koeficijenti (8) za svaki k

$$c_{0,k} = f[x_{k-1}] = f_{k-1}$$

$$c_{1,k} = f[x_{k-1}, x_k] = (f_k - f_{k-1}) / (x_k - x_{k-1}) \quad (8)$$

$$k = 1, \dots, n$$

Interpolacija metodom najmanjih kvadrata (Least Squares Interpolant) za N točaka oblikuje prikladan polinom reda $m < (N-1)$.

Polinom nastao metodom najmanjih kvadrata identičan je obliku $y_p(x) = p$, gdje je p matrica $N \times m$.

Interpolacija metodom konačnih elemenata FEM (Finite Element Method) koristi se za aproksimaciju po dijelovima [44].

4. Opis geomorfometrijski različitih područja

Biokovo je obalni planinski masiv s blago uzdignutim priobalnim dijelom. Na njega se nastavlja strmi stijenski dio s valovitom visoravni na vrhu, koja se prema zaleđu blago spušta. Današnje "boginjavo lice" Biokova sastavljeno od vrtača, škrapa, kamenica, špilja i jama, vrlo je složena podzemna hidrografska mreža [45], a obiluje prirodnim depresijama na kojima se zadržava voda zbog erozijom ili geološkom podlogom stvorenih uvjeta.

Papuk je najduža slavonska planina, raščlanjenog reljefa. S jedne strane nailazimo na blago zaravnjene oblike ispresijecane malim vodenim tokovima, dok se s druge strane izdižu obronci strmih i teško pristupačnih planinskih masiva. Opće karakteristike sliva su bujični, nestabilni vodotoci koji se formiraju na strmim obroncima planina, a glavni vodotoci u svojim dolinama meandriraju.

Prostor općine Nijemci karakterizira reljef neznatnih visinskih razlika (maksimalne visinske razlike od 32,5 m, i to isključivo zbog sjevernog dijela općine gdje se pojavljuju blaga uzvišenja). Općina Nijemci nalazi se u ravničarskom području, no zbog morfologije terena duž pružanja ravnjaka na sjevernom dijelu formirala se površinska i podzemna razvodnica (formiranje dva sliva). Budući da razvodnica nije nepropusna, oba sliva predstavljaju jedinstveni hidrološki sustav. Područje je znatno isprepleteno melioracijskim kanalima za osnovnu i detaljnu odvodnju, u koje najveći dio površinskog toka završava.

Prikupljeni podaci za sva tri izabrana područja obrađivani su s usklađenim koordinatnim razlikama prikazanim u tablici 1, te pokrivenosti područja prikazanim u tablici 2. S obzirom na broj redaka i stupaca, ukupan broj piksela za istražena područja iznosi 614400.

Tablica 1. Rezolucija u pikselima i koordinatne razlike u metrima za istražena područja

Stupci DMV	960	Redci DMV	640
Δx	4 800.00	Δy	3 200.00


Tablica 2. Koordinate istražena područja u metrima prema Hrvatskom državnom koordinatnom sustavu (HDKS)

BIOKOVO	maks. x	6.433.810,00	maks. y	4.794.210,00
	min. x	6.429.010,00	min. y	4.791.010,00
PAPUK	maks. x	6.468.540,00	maks. y	5.033.360,00
	min. x	6.463 740,00	min. y	5.030.160,00
NIJEMCI	maks. x	6.587 680,00	maks. y	5.003.690,00
	min. x	6.582 880,00	min. y	5.000.490,00

5. Rezultati i rasprava


Rasteri visinskih točaka, za sva tri područja, transformirani su u ASCII format te učitani u GIS softver otvorenog koda SAGA, gdje su u prvom koraku ponovno dobivene pravilne mreže točaka (5 x 5 metara) s pridruženim visinama. Uklonjene su depresije metodom prokopavanja (DEEPEEN DRAINAGE ROUTES) primjenjujući unaprijed oblikovan put otjecanja (SINK DRAINAGE ROUTE DETECTION) i metodu popunjavanja (FILL SINK).

U drugom koraku radi boljeg uočavanja razlika između podataka bez uklonjenih depresija i podataka s uklonjenim depresijama napravljeni su sjenčani prikazi (azimut = 315°, deklinacija = 45°, faktor uvećavanja=4) prije (slika 4.) i nakon uklanjanja depresija (slika 5.), prikazi izohipsama, te su izdvojena karakteristična područja s preklapljenim izohipsama (slike 6. i 7.). Prikazi izdvojenih karakterističnih područja preklapanjem izohipsi koje prikazuju teren prije uklanjanja depresija s prikazom izohipsi nakon uklanjanja depresija metodom prokopavanja i metodom popunjavanja, daju nam uvid u promjenu topografije na osnovi dva modula za uklanjanje depresija.



Slika 4. DMV područja Biokovo (tablica 2.)


Sjenčani prikaz područja Biokovo pokazuje izuzetno razveden i strm teren s mnoštvom depresija. Na slici 5. nakon uklanjanja depresija uočavaju se prokopani kanali za odvodnju vode iz depresija (lijevo), te zapunjene depresije do točke prelijevanja



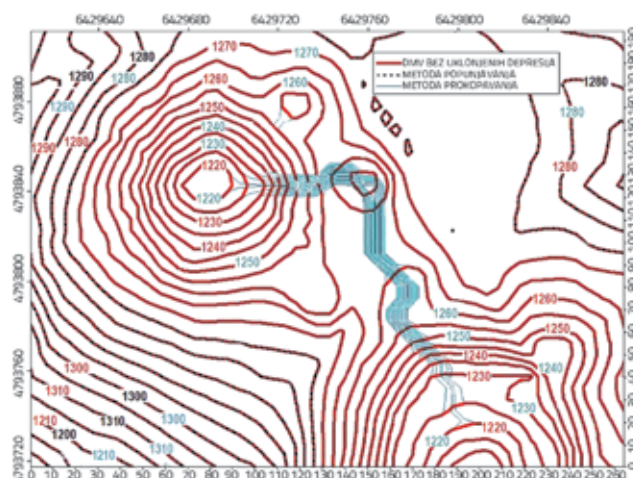
Slika 5. DMV Biokovo, depresije uklonjene metodom prokopavanja (lijevo) i popunjavanja (desno)

(desno). Već na prvi pogled uočava se da je morfometrija terena znatno izmijenjena metodom popunjavanja (slika 5. desno), te možemo pretpostaviti da će na području Biokova bolje rezultate dati metoda prokopavanja.

Na preklapljenim prikazima prije i nakon uklanjanja depresija na izdvojenim dijelovima nastalih nakon uklanjanja depresija dvjema metodama (slika 6.), vidimo da metoda prokopavanja mijenja topografiju na uskom području kanala koji vode od jedne do druge depresije, zadržavajući pri tome visine svih izohipsi, za razliku od metode popunjavanja koja izohipse od visine 1220 metara do visine od 1275 metara zapunjava i pretvara u ravnu površinu.




Slika 7. DMV Biokovo s prikazom depresija i hidrografskom mrežom



Slika 6. Izdvojeno područje DMV Biokovo prikazano izohipsama


Na DMV Biokovo u izvornom obliku dobiven interpolacijskom metodologijom (slika 7.), provedena je korekcija DMV-a metodom popunjavanja i metodom prokopavanja, koji su zatim predstavljali bazu za izradu hidrološke simulacije tečenja po površini terena.



Slika 8. Izdvojeni dio DMV Biokovo s prikazom depresija i hidrografskom mrežom

Iz te baze kao rezultat dobivena je hidrografska mreža, odnosno trajektorije tečenja po površini terena, uzduž vodnih brazda i manjih vodnih tijela. Na prvi pogled, usporedbom tih dvaju modela tečenja po površini terena, uzduž brazda i manjih vodnih tijela, nema značajne razlike u tečenju. No, uzimajući u obzir

činjenicu da je Biokovo kao teren izuzetno razveden i strm, s mnoštvom depresija (u ovom primjeru zauzimaju i do 1,13 % površine), kada se depresije popune, morfometrija terena se znatno izmijeni, pa tok vode ne prati najniže točke terena, već ih zapunjava i preko njih pravocrtno prelazi do sljedeće denivelacije terena (slika 8., crvene strelice). Vidljivo je da što je udio stvarnih depresija veći u promatranom prostoru, to se značajnije hidrografska slika mijenja. Metoda prokopavanja respektira pojavnost depresija, rigola i sličnih formacija na terenu u puno većoj mjeri nego metoda popunjavanja, pa je vidljivo da tok vode prati depresije i uvijek slijedi područje s nižom nadmorskom visinom, kako je to stvarno na terenu (slika 8., zelene strelice). Sjenčani prikaz područja Papuk (slika 9.) pokazuje blago nagnut teren s vrlo malo depresija, koji blago raste od juga prema sjeveru. Područja u sjeni duž kojih otječe voda izraženi su na modelu na kojem nisu uklonjene depresije. Odvodnja vode na području kontinuiranih nagiba usmjerena je sa viših područja na sjeveru prema nižima na jugu duž usjeka koji u topografiji izvornog reljefa postoje sprječavajući pojavu depresija.




Slika 9. DMV područja Papuk (tablica 2.)

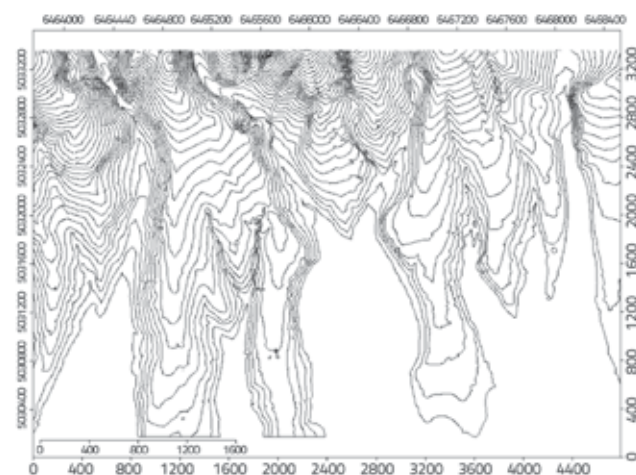
Na slici 10., koja prikazuje reljef sjenčanjem, uočavamo vrlo male promjene topografije reljefa metodom prokopavanja (lijevo), za razliku od velikih promjena nakon uklanjanja depresija metodom popunjavanja (desno). Ovaj prikaz je dobar primjer kako sama vizualizacija može zavarati. Iako je na prvi pogled promjena morfometrije velika, vidljivo je da su velika popunjavanja, odnosno promjene topografije isključivo na južnim dijelovima istraživanog područja.

Da se bolje objasne nedostaci vizualizacije na području Papuk, napravljen je prikaz cijelog istraživanog područja izohipsama. Promatrajući sliku 11. koja prikazuje reljef nakon uklanjanja depresija metodom popunjavanja, vidimo da dio izohipsi "izlazi" iz modela, odnosno nije zatvoreno unutar istraživanog područja. Kako program takvu izohipsu ne može pravilno interpretirati unutar modula za sjenčanje na modelu s uklonjenim depresijama, javljaju se velike promjene u geomorfometriji koje na stvarnom modelu s uklonjenim depresijama ne postoje. U prilog ovoj teoriji idu južni dijelovi područja koji sadrže zatvorene izohipse unutar modela, na kojima se ne vidi promjena u geomorfometriji. Za

razliku od područja Biokovo, na istraživanom području Papuk, ako izuzmemo iz razmatranja nepravilno interpretirane izohipse, iz ova dva prikaza ne možemo biti sigurni koja metoda daje bolje rezultate.




Slika 10. DMV Papuk, depresije uklonjene metodom prokopavanja (gore) i popunjavanja (dolje)



Slika 11. DMV Papuk, depresije uklonjene metodom popunjavanja

Preklopljeni prikazi izohipsama prije i nakon uklanjanja depresija na izdvojenim dijelovima područja Papuk (slika 12.) daju nam


bolji uvid u geomorfometrijske razlike na istraživanom području sa zatvorenim izohipsama.



Slika 12. Izdvojeno područje DMV Papuk prikazano izohipsama

Kao što je pretpostavljeno, područje na kojem su izohipse zatvorene unutar modela vrlo malo mijenja geomorfometriju bez obzira na to radi li se o metodi prokopavanja ili metodi popunjavanja. Kako na području gotovo i nema depresija (u ovom primjeru udio je 0,05 % površine), metoda popunjavanja izmijenila je geomorfometriju na manjim područjima popunjavajući depresije, a metoda prokopavanja stvarajući uske bujične tokove do depresija, no visine izohipsi i uporabom jedne i uporabom druge metode ostale su nepromijenjene. Ovakvom vizualizacijom na području Papuka, gdje je broj depresija mali, teško je utvrditi koja od dviju ispitivanih metoda daje bolje rezultate. Takvu konstataciju potvrđuju i rezultati hidroloških simulacija tečenja po površini terena, duž rigola i sličnih formacija (slike 13. i 14.). Naime, preklapom hidrografske mreže za oba slučaja izmjena DMV-a, nije uočena neka značajna razlika u simulaciji, a trajektorije tečenja se gotovo svuda poklapaju.

Sjenčani prikaz područja Nijemci (slika 15.) pokazuje ravničarski teren s velikim brojem melioracijskih kanala, te nešto depresija.




Slika 13. DMV Papuk s prikazom depresija i hidrografskom mrežom

Dio kanala također se ponaša kao depresija pa su u izračun, odnosno u modul za uklanjanje depresija uzeti i oni.





Slika 14. Izdvojeni dio DMV Papuk s prikazom depresija i hidrografskom mrežom



Slika 15. DMV područja Nijemci (tablica 2.)

Na slici 16. koja prikazuje teren nakon uklanjanja depresija dvjema metodama uočavamo da prikaz reljefa sjenčanjem nakon metode uklanjanja depresija prokopavanjem (lijevo) pokazuje


promjenu topografije, no znatno manje nego metoda popunjavanja (desno), koja popunjava velike depresije i dio melioracijskih kanala koji očitno postoje na terenu i koje, u kontekstu definiranja cjelovite i vjerodostojne hidrografske mreže, zasigurno ne bi trebalo popuniti. Iako je često teško utvrditi koje depresije predstavljaju stvarne značajke terena, a koje računalne pogreške nastale netočnim izračunom DMV-a, na ovakvom terenu je ovakvo razlučivanje jednostavnije. Za manje depresije unutar melioracijskih kanala za odvodnju vode ne možemo biti sigurni jesu li to




Slika 16. DMV Nijemci, depresije uklonjene metodom prokopavanja (lijevo) i popunjavanja (desno)

stvarne značajke terena ili samo pogreška DMV-a, Međutim, melioracijski kanali koje program prepoznaje kao depresije sigurno postoje na terenu i kao takve ne treba ih uzeti u izračun uklanjanja depresija, pa promatrajući sliku 16. smatramo da će metoda prokopavanja na ovakvom terenu dati bolje rezultate nego metoda popunjavanja depresija.


Preklopljeni prikazi izohipsama prije i nakon uklanjanja depresija na izdvojenim dijelovima područja Nijemci (slika 17.) daju nam bolji uvid u topografske razlike na istraživanom području punom melioracijskih kanala, stvarnih depresija i depresija nastalih pogrešnim izračunom digitalnog modela.



Slika 17. Izdvojeno područje DMV Nijemci prikazano izohipsama



Slika 19. Izdvojeni dio DMV Nijemci s prikazom depresija i hidrografskom mrežom



Slika 18. DMV Nijemci s prikazom depresija i hidrografskom mrežom

Metoda prokopavanja mijenja topografiju na manjem uskom području novonastalih kanala, dok metoda popunjavanja znatno mijenja topografiju, gdje oblikuje potpuno novu konfiguraciju terena (izohipsa visine 84 metra). Usporedbom hidrografskih mreža izrađenih za oba modela modifikacije DMV-a, sa simulacijom tečenja u izvornom obliku, vidljivo je da u ovom primjeru treba biti posebno oprezan (slika 18). Naime, niti jedna od simulacija tečenja, prema modificiranom DMV-u, ne respektira postojeće melioracijske kanale i prema

tome ne forsira tečenje s okolnog terena u te kanale. Metoda popunjavanja zapunjuje depresije i melioracijske kanale metodološki na isti način, stvarajući svoje paralelne rigole, koji u stvarnosti ne postoje (slika 19., crvene strelice), dok se metodom prokopavanja oko 10 % tečenja forsira po melioracijskim kanalima, a ostali se tok odvija po principu tečenja u prvu nižu kotu terena (slika 19., zelene strelice). Stoga se, u ovakvom slučaju specifičnog ravničarskog okruženja prosijecanog sustavom kanala površinske odvodnje, ne preporuča niti jedna od promatranih metoda modifikacije DMV, kako se slika tečenja ne bi značajno izmijenila, a onda i krivo interpretirala. Mora se još istaknuti slučaj kad se na takvom ravničarskom području ne nalaze melioracijski kanali. Tada bi se prednost dala metodi prokopavanja, Naime, s obzirom na to da su metodom popunjavanja velike površine pridružene depresijama, znatno je izmijenjena geomorfometrija terena.



Postupak popunjavanja depresija podiže visinu čelija gdje su depresije identificirane, pa većim visinskim odrednicama promatranih zona rezultira većim pozitivnim odstupanjima nadmorske visine. Podizanje ovih okruženja depresije pak smanjuje vrijednosti izračunanog nagiba za ista područja, što u konačnici dovodi do negativnog odstupanja nagiba. Taj efekt ima osobito negativan utjecaj u slivnim područjima koja su u ravničarskim i u nižim zaravljanim prostornim okruženjima, kao što su poljoprivredne površine. U velikim ravninama, kao što su one koje se pojavljuju u slivu rijeke Dunav, DMV s grubljom

prostornom rezolucijom ne daje kvalitetnu hidrografsku mrežu u domeni oba tečenja: po površini terena i duž vodotoka višeg i nižeg reda. Doista, kada je širina površinskih tokova uključivo i melioracijskih kanala u ravninama manja od veličine piksela u DMV-u, nemoguće je pouzdano definirati hidrografsku mrežu bilo kojim od spomenutih algoritama iz DMV-a.


Podaci DMV-a s uklonjenim depresijama za sve modele učitanu su u GIS softver IDRISI, gdje su napravljeni prikazi razlika piksela prije i nakon uklanjanja depresija pojedinom metodom. Također su napravljeni histogrami (slike 20., 21. i 22.) koji na apscisi prikazuju razlike u metrima, a na ordinati broj piksela, te tablice s numeričkim vrijednostima razlika između dva modela. Za svako istraživano područje napravljen je izračun ukupno promijenjenih piksela (tablica 3.), gdje vrijednost 1 predstavlja broj promijenjenih, a vrijednost 0 broj nepromijenjenih piksela od ukupno (614400) nakon primjene pojedine metode uklanjanja depresija. Radi lakše usporedbe izračunani su i udjeli u postocima za obje vrijednosti.

Na svakom modelu izračunana je i razlika visina u metrima za svaki promijenjeni piksel, što je poslužilo za izračun ukupnog promijenjenog volumena (tablica 4.). Uklanjanje depresija metodom prokopavanja mijenja teren tako da snižava njegovu visinu, pa su prikazane vrijednosti negativne, dok uklanjanje depresija metodom popunjavanja mijenja teren tako da podiže visinu terena, pa su prikazane vrijednosti pozitivne.


Iz tabličnih vrijednosti histograma za područje Biokovo,



Slika 20. Histogrami razlika između modela s uklonjenim depresijama metodom prokopavanja (lijevo) i metodom popunjavanja (desno) u odnosu na model na kojem nisu uklonjene depresije (područje Biokovo), na apscisi su prikazane razlike u metrima, a na ordinati broj piksela



Slika 21. Histogrami razlika između modela s uklonjenim depresijama metodom prokopavanja (lijevo) i metodom popunjavanja (desno) u odnosu na model na kojem nisu uklonjene depresije (područje Papuk), na apscisi su prikazane razlike u metrima, a na ordinati broj piksela



Slika 22. Histogrami razlika između modela s uklonjenim depresijama metodom prokopavanja (lijevo) i metodom popunjavanja (desno) u odnosu na model na kojem nisu uklonjene depresije (područje Nijemci), na apscisi su prikazane razlike u metrima, a na ordinati broj piksela

Tablica 3. Broj promijenjenih piksela i udio u ukupnom broju piksela modela nakon uklanjanja depresija

Područje/model	Metoda prokopavanja				Metoda popunjavanja			
	Broj piksela		Postotak u modelu		Broj piksela		Postotak u modelu	
	1	0	1	0	1	0	1	0
DMV Biokovo	6295	608105	1,02	98,98	71256	543144	11,60	88,40
DMV Papuk	4736	609664	0,77	99,23	4476	609924	0,73	99,27
DMV Nijemci	71090	543310	11,57	88,43	225068	389332	36,63	63,37

za metodu prokopavanja, uočavamo na 2368 od ukupno 6295 piksela razlike u geomorfometriji unutar jednog metra (definirana točnost digitalnog modela je 0,9 metara). Također uočavamo da većih pogrešaka gotovo da i nema. Za metodu popunjavanja vidljivo je da je najveći broj piksela opterećen manjim razlikama. Broj piksela s razlikom do pola metra je 5616, a onih s razlikom od pola do jednog metra je 4577. Smanjivanje broja piksela koji nose veće razlike događa se postupno sve do piksela koji nose najviše razlika. Ovakva raspodjela razlika visina između dva novonastala modela pokazuje da model na kojem su uklonjene depresije metodom prokopavanja manje mijenja topografiju (većina piksela s razlikama je unutar dopuštenog odstupanja) u odnosu na model na kojem su depresije uklonjene metodom popunjavanja.

Iz tabličnih vrijednosti histograma za područje Papuk uočavamo da nešto bolje rezultate pokazuje metoda popunjavanja. Kod metode popunjavanja većina piksela nalazi se unutar razlike od jednog metra (samo 77 piksela ima razliku visina veću od metra), a 2738 piksela od ukupno 4476 na kojima su izračunane razlike u visini nalaze se unutar vrijednosti od deset centimetara.

Iz slike 22. i iz tabličnih vrijednosti histograma za područje Nijemci uočavamo da bolje rezultate pokazuje metoda prokopavanja (49408 piksela nalazi se unutar razlike od 0,1 metra), dok kod modela gdje su depresije uklonjene metodom popunjavanja uočavamo da broj piksela na kojima su promijenjene visine ravnomjerno opada, no pokazuje veće vrijednosti.

Za područje Biokova iz tablice 3., koja prikazuje razlike nakon uklanjanja depresija metodom prokopavanja i metodom popunjavanja, u odnosu na model bez uklonjenih depresija, vidimo da metoda popunjavanja mijenja digitalni model na

znatno više piksela nego metoda prokopavanja (1,02 % u odnosu na 11,60 % promijenjenih piksela modela), a promijenjeni volumen (tablica 4.) znatno je manji za metodu prokopavanja u odnosu na metodu popunjavanja, što pokazuje da je model nastao nakon uklanjanja depresija metodom prokopavanja manje promijenio geomorfometriju.

Tablica 4. Ukupan promijenjeni volumen nakon uklanjanja depresija metodom prokopavanja i metodom popunjavanja, [m³]

Područje	Prokopavanje	Popunjavanje
DMV Biokovo	- 1.011.677,55	16.172.095,19
DMV Papuk	- 470.683,31	16.770,39
DMV Nijemci	- 32.332,31	1.163.524,16

Iz tablice 3. vidljivo je da za područje Papuka razlike u primjeni dviju metoda nisu velike (0,77 % u odnosu na 0,73 % promijenjenih piksela modela). Kao što je spomenuto, područje Papuka nije područje s velikim brojem depresija, pa topografija terena nakon uklanjanja depresija nije bitno promijenjena niti metodom prokopavanja niti metodom popunjavanja. Promatrajući broj promijenjenih piksela i uspoređujući ih sa slikom 21. možemo potvrditi da je vizualizacija područja Papuk (slika 10. desno) na modelu s uklonjenim depresijama metodom popunjavanja dala netočne rezultate.

Za razliku od područja Biokovo gdje je udio promijenjenih piksela bio znatno manji za metodu prokopavanja, razlike na području Papuk premale su za definiranje preporučene metode. Izračunom promijenjenog volumena (tablica 4.) vidimo da je

taj volumen nastao metodom popunjavanja znatno manji od promijenjenog volumena nastalog metodom prokopavanja, što pokazuje da metoda uklanjanja depresija metodom popunjavanja na području Papuk daje bolje rezultate, odnosno manje utječe na geomorfometriju.

Za područje Nijemci razlike između modela bez uklonjenih depresija i modela s uklonjenim depresijama (tablica 3.) uočljive su na velikom broju piksela i za metodu prokopavanja (11,57 %) i za metodu popunjavanja (36,63 %). To je uvjetovano prostornom rezolucijom modela i malim visinskim razlikama, koje na ravničarskom području zanemaruju većinu karakterističnih oblika (melioracijski kanali, obrambeni nasipi...). Najuočljivije razlike između primjene dviju metoda uklanjanja depresija, odnosno utjecaja na morfometriju reljefa vidljive su u izračunu volumena promjena (tablica 4.), gdje uklanjanje depresija metodom prokopavanja manje mijenja geomorfometriju digitalnog modela područja Nijemci.

Na osnovi navedenih razmatranja (izračun ukupno promijenjenih piksela i ukupno promijenjenog volumena) donosi se preporuka o primjeni pojedine metode za tri istražena područja, što je prikazano u tablici 5.

Tablica 5. Preporučene metode popunjavanja depresija za pojedina područja

Područje	Preporučena metoda uklanjanja depresija
Biokovo	prokopavanje
Papuk	popunjavanje
Nijemci	prokopavanje

6. Zaključak

Za podatke tri izabrana istražena područja (Biokovo, Papuk i Nijemci) rezolucije 5 x 5 m, usklađene su veličine područja istraživanja na 4800 x 3200 m, odnosno 960 x 640 piksela, što je omogućilo lakšu usporedbu rezultata. Iz geomorfometrijskih analiza (model nastao sjenčanjem, prikaz izohipsama, preklopi) došlo se do određenih zaključaka, no statističke analize (izračun broja promijenjenih piksela i volumena) sa sigurnošću definiraju koja metoda uklanjanja depresija manje mijenja geomorfometriju pojedinog područja.

Područje Biokovo prekriveno je većim brojem stvarnih i umjetnih depresija, pri čemu metoda prokopavanja mijenja topografiju na uskom području kanala koji vode od jedne depresije do druge, pri tome zadržavajući visine svih izohipsi, za razliku od metode popunjavanja koja spajajući depresije oblikuje veća popunjena ravna područja. Za područje Biokovo metoda prokopavanja mijenja visine na znatno manjem broju piksela digitalnog modela, a promjena volumena područja Biokovo manja je za model na kojem su depresije uklonjene metodom prokopavanja. Ovi rezultati zajedno s rezultatima geomorfometrijskih analiza pokazuju da je za područje s većim brojem depresija i velikim visinskim razlikama kao što je Biokovo, metoda uklanjanja depresija prokopavanjem manje promijenila geomorfometriju.

Takav zaključak dokazuje i simulacija tečenja po površini terena, koja daje prednost metodi prokopavanja jer uzima u obzir pojavnost depresija, rigola i sličnih formacija na terenu u puno većoj mjeri nego metoda popunjavanja, gdje posljedično tok vode prati depresije i uvijek slijedi područje s nižom nadmorskom visinom, kako je to stvarno na terenu.

Za područje Papuk donošenje zaključaka iz geomorfometrijskih analiza treba uzeti sa zadržkom, jer na rubovima modela "nezatvorene" izohipse onemogućavaju točan izračun modela metodom popunjavanja, stvarajući nerealan i znatno izmijenjen model. No i izuzimajući područja netočnog izračuna, rezultati geomorfometrijskih analiza ne mogu jednoznačno definirati prihvatljiviju metodu uklanjanja depresija. Iz prikaza s izohipsama uočljivo je da je metoda popunjavanja izmijenila geomorfometriju na manjim područjima, dok je metoda prokopavanja stvorila uske drenažne prolaze do depresija, no visine izohipsi i uporabom jedne i uporabom druge metode ostale su nepromijenjene. Hidrološka simulacija tečenja za oba modela također ne daje značajnije razlike među njima, pa se s tog aspekta ne daje prednost niti jednoj metodi.

Za razliku od područja Biokova gdje su razlike u promjeni broja piksela bile značajne, područje brežuljkastog Papuka pokazuje male razlike u promjeni visina, a tek izračunom promijenjenog volumena možemo zaključiti da za područje Papuk bolje rezultate uklanjanja depresije daje metoda popunjavanja.

Za područje Nijemci metoda uklanjanja depresija prokopavanjem pokazuje promjenu topografije, no znatno manje nego metoda popunjavanja, koja popunjava velike i ugniježdene depresije, ali i dio kanala koje zasigurno ne bi trebalo popuniti stvarajući potpuno novu konfiguraciju terena. Iako i jedna i druga metoda pokazuju veliki broj piksela s promijenjenim visinama nakon uklanjanja depresija, razlike uporabe dviju metoda su velike. Izračun ukupnog promijenjenog volumena zajedno s rezultatima geomorfometrijskih analiza omogućuje preporuku za uporabu metode prokopavanja za područje Nijemci, ispresijecano velikim brojem kanala i malih visinskih razlika. No, hidrološka simulacija tečenja ne govori u prilog niti jednoj od metoda, zbog specifičnosti područja u kojem melioracijski kanali trebaju imati prednost kad je riječ o kriterijima tečenja po terenu.

Izračun ukupno promijenjenih piksela za obje metode je velik, pa unatoč relativnoj prednosti jedne metode u odnosu na drugu bez podataka o stvarnom položaju riječnog toka, metode kojima se ostvaruje simulacija toka na ravnim dijelovima treba uzeti s rezervom, jer riječne mreže nastale ovakvim algoritmima mogu znatno odstupati od stvarnih na terenu. Stoga postoji potreba da se integriraju a priori znanja o stvarnom položaju riječnih tokova kako bi se hidrološke simulacije mogle testirati i korigirati.

Uklanjanje depresija na digitalnom modelu visina preduvjet je za geomorfometrijske analize, pa je izbor optimalne metode uklanjanja depresija ovisno o geomorfometriji reljefa ključan faktor za kreiranje minimalno modificiranog digitalnog modela visina.

Budući da mnogi GIS računalni programi koji imaju hidrološke simulacije i izračune tečenja predviđaju, kao početni korak modifikaciju DMV-a uporabom "SINK" naredbe, koja će se od

metoda primijeniti u modifikaciji DMV-a treba odrediti ovisno o topografiji terena, udjelu stvarnih depresija i nekih specifičnosti područja. Preporuka je da se metoda prokopavanja uvijek primjenjuje tamo gdje je teren strm, dinamičan i pun depresija, rigola i sl. U umjerenijim terenima blažega nagiba s vrlo malim udjelom depresija može se zapravo primijeniti bilo koja metoda jer su rezultati vrlo bliski i slični. Međutim, u ravničarskim područjima vrlo malog nagiba i minimalnih denivelacija, u slučaju da područje nije isprepleteno umjetnom mrežom površinske odvodnje, prednost se daje metodi prokopavanja, jer su metodom popunjavanja velike površine pridružene depresijama, a time se znatno mijenja geomorfometrija terena i slika otjecanja sa sliva.

Primjena bilo kojeg od predloženih algoritama utječe na izmjenu stvarnih smjerova tečenja po terenu. Njihova izmjena DMV-a, a samim tim i simulacije hidrografske mreže, ovisi o mnogim posebnostima područja (veličina sliva koji se analizira, njegova topografija – strmi teren, blagi, mjerilo u kojem se radi, te niz drugih

mikrolokacijskih odrednica koje lokalno mijenjaju smjer tečenja po površini i duž vodotoka višeg i nižeg reda. U svakom slučaju, prijedlog autora je da se prilikom korištenja GIS alata u hidrološkim simulacijama upozori na dodatni oprez, osobito onih kod kojih nije dan algoritam za popunjavanje depresija na izbor, već je ugrađen u modul automatizmom. Drugim riječima, ako je takva opcija, treba međusobno usporediti rezultate što više dostupnih GIS modula za modifikaciju DMT-a s povijesnim – stvarnim podacima na terenu, gdje će se ovakvim pristupom izbjeći stvaranje lažnih trajektorija tečenja. Alternativa tom postupku je koristiti novije hibridne algoritme popunjavanja depresija, koji su upravo proizašli iz spoznaje o ograničenjima postojećih algoritama.

Zahvala

Ovo istraživanje je provedeno u okviru projekta 1924 - FORENZA (Advanced Forest Ecosystem Services Assessment) uz potporu Hrvatske zaklade za znanost.

LITERATURA

- [1] URL:<http://www.dgu.hr/proizvodi-i-usluge/sluzbene-drzavne-karte-i-podaci-topografske-izmjere/digitalni-model-reljefa-dmr.html> (13.10.2015)
- [2] Kunštek, D.: *Unapređenje parametarskih metoda za proračun otjecanja informatičkom tehnologijom*, doktorski rad, Građevinski fakultet Sveučilišta u Zagrebu, Zagreb, 2010.
- [3] Bhuyian, M., Kalyanapu, A., Nardi, F.: Approach to Digital Elevation Model Correction by Improving Chaneel Conveyance, *Journal of Hydrologic Engineering*, 20 (2015) 5, pp. 1-10, [https://doi.org/10.1061/\(ASCE\)HE.1943-5584.0001020](https://doi.org/10.1061/(ASCE)HE.1943-5584.0001020)
- [4] *Primijenjena hidrologija*, stručni seminar, Društvo građevinskih inženjera Zagreb i Hrvatsko hidrološko društvo: Zagreb, 2002.
- [5] Cheng, C.T., Ou, C.P., Chau, K.W.: Combining a fuzzy optimal model with a genetic algorithm to solve multi-objective rainfall-runoff model calibration, *Journal of Hydrology*, 268 (2002) 1-4, pp. 72-86, [https://doi.org/10.1016/S0022-1694\(02\)00122-1](https://doi.org/10.1016/S0022-1694(02)00122-1)
- [6] Kunštek, D., Ocvirk, E., Carević, D., Novak, K., Halkijević, I.: Implementacija znanja i tehnika informatičke znanosti u CRRS modele, 4. hrvatska konferencija o vodama, Opatija, pp. 953-960, 2007.
- [7] Jordan, G., Rompaey, A., Szilassi, P., Csillag, G., Mannaerts, C., Woldai, T.: Historical land use changes and their impact on sediment fluxes in the Balaton basin (Hungary), *Agriculture, Ecosystems & Environment*, 108 (2005) 2, pp. 119-133, <https://doi.org/10.1016/j.agee.2005.01.013>
- [8] Bekić, D., Kerin, I.: Rekonstrukcija željezničkih mostova-iskustva iz Irske, In: Lakušić S, editor, *Građenje prometne infrastrukture*, Zagreb, Građevinski fakultet Sveučilišta u Zagrebu, pp. 119-56, 2012.
- [9] O'Callaghan, J.F., Mark, D.M.: The extraction of drainage networks from digital elevation data, *Computer Vision, Graphics, and Image Processing*, 28 (1984), pp. 323-344, [https://doi.org/10.1016/S0734-189X\(84\)80011-0](https://doi.org/10.1016/S0734-189X(84)80011-0)
- [10] Fairfield, J., Leymarie, P.: Drainage networks from grid digital elevation models, *Water Resources Research*, 27 (1991) 5, pp. 709-717, <https://doi.org/10.1029/90WR02658>
- [11] Lea, N.J.: An aspect driven kinematic routing algorithm, In Parson, A.J., Abrahams, A.D., *Overland Flow: Hydraulics And Erosion Mechanics*, London, pp. 147-175, 1992.
- [12] Goodchild, M. F.: *Geospatial analysis, 4th Edition*, University College London, UC Santa Barbara, 2013.
- [13] Wilson, J.P., Aggett, G., Yongxin, D., Lam, C.S.: Water in the Landscape: A Review of Contemporary Flow Routing Algorithms, *Advances in Digital Terrain Analysis*, (eds. Zhou, Q., Lees, B., Tang, G.), pp. 213-236, 2008.
- [14] Tarboton, D.G.: A new method for the determination of flow directions and upslope areas in grid digital elevation models, *Water resources research*, 33 (1997) 2, pp. 309-319, <https://doi.org/10.1029/96WR03137>
- [15] Cvitanović, A.: *Geografski rječnik*, Hrvatsko geografsko društvo Zadar, Filozofski fakultet, Matica hrvatska, Zadiz d.o.o., 2002.
- [16] Mark, D.M.: Network models in geomorphology, In M. G. Anderson (ed), *Modeling Geomorphological Systems*, pp. 73-97, 1987.
- [17] Gajski, D.: *Rasterbasierte Geländeoberflächenanalysen zwecks Ableitung der Strukturlinien im digitalen Geländemodell*, Saarbrücken, Germany: Südwestdeutscher Verlag für Hochschulschriften Aktiengesellschaft & Co., 2009 (monografija).
- [18] Martz, L. W., Garbrecht, J.: The treatment of flat areas and depressions in automated drainage analysis of raster digital elevation models, *Hydrological Processes*, 12 (1998) 6, pp. 843-855, [https://doi.org/10.1002/\(SICI\)1099-1085\(199805\)12:6<843::AID-HYP658>3.0.CO;2-R](https://doi.org/10.1002/(SICI)1099-1085(199805)12:6<843::AID-HYP658>3.0.CO;2-R)
- [19] Lindsay, J.B., Creed, I.F.: Distinguishing actual and artefact depressions in digital elevation data, *Computers & Geosciences*, 32 (2006) 8, pp. 1192-1204, <https://doi.org/10.1016/j.cageo.2005.11.002>
- [20] Barták, V.: New computer program for digital terrain analysis, *GIS Ostrava 2010.*, (URL: http://gisak.vsb.cz/GIS_Ostrava/GIS_Ova_2010/sbornik/Lists/Papers/EN_3_5.pdf)

- [21] Soille, P.: Optimal removal of spurious pits in grid digital elevation models, *Water Resources Research*, 40 (2004) 12.
- [22] Lindsay, J.B., Creed, I.F.: Removal of artifact depressions from digital elevation models: towards a minimum impact approach, *Hydrological Processes*, 19 (2005), pp. 3113–3126, <https://doi.org/10.1002/hyp.5835>
- [23] URL: www.cae.utexas.edu/prof/maidment/giswr2012/TermPaper/Jackson.pdf (29.01.2017.)
- [24] Srivastava, A.: Comparison of Two Algorithms for Removing Depressions and Delineating Flow Networks From Grid Digital Elevation Models, Doktorski rad, Blacksburg, 2000., (URL: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.538.4854&rep=rep1&type=pdf> (29.01.2017.))
- [25] Zhu, D., Ren, Q., Xuan, Y., Chen, Y., Cluckie, I.D.: An effective depression filling algorithm for DEM-based 2-D surface flow modelling, *Hydrology and Earth System Sciences*, 17 (2013), pp. 495–505, <https://doi.org/10.5194/hess-17-495-2013>
- [26] Lindsay, J.B.: Efficient hybrid breaching-filling sink removal methods for flow path enforcement in digital elevation models, *Hydrological Processes*, 30 (2016) 6, pp. 846–857, <https://doi.org/10.1002/hyp.10648>
- [27] Jensen, S., Domingue, J.O.: Extracting topographic structure from digital elevation data for geographic information system analysis, *Photogrammetric Engineering and Remote Sensing*, 54 (1988) 11, pp. 1593–1600.
- [28] Grimaldi, S., Nardi, F., Di Benedetto, F., Istanbuluoglu, E., Bras, R.L.: A physically-based method for removing pits in digital elevation models, *Advances in Water Resources*, 30 (2007) 10, pp. 2151–2158.
- [28] Grimaldi, S., Nardi, F., Di Benedetto, F., Istanbuluoglu, E., Bras, R.L.: A physically-based method for removing pits in digital elevation models, *Advances in Water Resources*, 30 (2007) 10, pp. 2151–2158, <https://doi.org/10.1016/j.advwatres.2006.11.016>
- [29] Zhu, D., Ren, Q., Xuan, Y., Chen, Y., Cluckie, I. D.: An effective depression filling algorithm for DEM - based 2-D surface flow modelling, *Hydrology and Earth System Sciences*, 17 (2013), pp. 495–505, <https://doi.org/10.5194/hess-17-495-2013>
- [30] Jensen, S.K., Trautwein, C.M.: Methods and applications in surface depression analysis, *Proceedings of Auto-Carto 8*, Baltimore, pp. 137–144, 1987.
- [31] Mark, D.M.: Automated detection of drainage networks from digital elevation models, *Cartographica*, 21 (1984) 2–3, pp. 168–178, <https://doi.org/10.3138/10LM-4435-6310-251R>
- [32] Planchon, O., Darboux F.: A fast, simple and versatile algorithm to fill the depressions of digital elevation models, *Catena*, 46 (2001), pp. 159–176, [https://doi.org/10.1016/S0341-8162\(01\)00164-3](https://doi.org/10.1016/S0341-8162(01)00164-3)
- [33] Rieger W.: A phenomenon-based approach to upslope contributing area and depressions in DEMs, *Hydrological Processes*, 12 (1998) 6, pp. 857–872, [https://doi.org/10.1002/\(SICI\)1099-1085\(199805\)12:6<857::AID-HYP659>3.0.CO;2-B](https://doi.org/10.1002/(SICI)1099-1085(199805)12:6<857::AID-HYP659>3.0.CO;2-B)
- [34] Martz, L.W., Garbrecht, J.: An outlet breaching algorithm for the treatment of closed depressions in a raster DEM, *Computers and Geosciences*, 25 (1999) 7, pp. 835–844, [https://doi.org/10.1016/S0098-3004\(99\)00018-7](https://doi.org/10.1016/S0098-3004(99)00018-7)
- [35] Poggio, I., Soille, P.: Influence of Spurious Pit Removal Methods from SRTM on River Network Positioning, *Proceedings of Geomorphometry*, Zurich, pp. 231 – 236, 2009.
- [36] Brenning, A.: SAGA Geoprocessing and Terrain Analysis in RSAGA (URL: <https://cran.r-project.org/web/packages/RSAGA/vignettes/RSAGA-landslides.pdf> (29.01.2017.))
- [37] Wang L., Liu, H.: An efficient method for identifying and filling surface depressions in digital elevation models for hydrologic analysis and modelling, *International Journal of Geographical Information Science*, 20 (2006) 2, pp. 193–213, <https://doi.org/10.1080/13658810500433453>
- [38] Tarboton, D.G., Bras, R.L., Rodriguez Iturbe, I.: On the extraction of channel networks from digital elevation data, *Hydrological Processes*, 5 (1991) 1, pp. 81–100, <https://doi.org/10.1002/hyp.3360050107>
- [39] De Smith, M., Goodchild, M.F. Longley, P.A.: Geospatial Analysis, A Comprehensive Guide to Principles, Techniques and Software Tools – 5th edition, 2015., (URL: <http://www.spatialanalysisonline.com/Extract.pdf> (30.01.2017))
- [40] O'Callaghan, J.F.: The Extraction Of Drainage Networks From Digital Elevation Data, *Computer Vision, Graphics, and Image Processing*, 28 (1984) 3, pp. 323–344, [https://doi.org/10.1016/S0734-189X\(84\)80011-0](https://doi.org/10.1016/S0734-189X(84)80011-0)
- [41] Frančula, N., Lapaine, M.: *Geodetsko-geoinformatički rječnik*, Republika Hrvatska, Državna geodetska uprava, Zagreb, 2008.
- [42] Schumaker, L.L.: Fitting surface to scattered data, *Approximation Theory II* (ed. Lorentz, G.G., Chui C.K., Schumaker L.L.), Academic Press, New York, pp. 203–268, 1976.
- [43] Bosner, N.: *Interpolacija i aproksimacija splajnovima*, Interna skripta, PMF, Matematički odsjek, Zagreb (URL: http://web.math.pmf.unizg.hr/~nela/nmfmpreradavanja/nmfm_splajnovi.pdf (05.11.2013.))
- [44] Finlayson, B.A.: Nonlinear analysis in chemical engineering, *McGraw-Hill International Book Co.*, New York, 1980.
- [45] Magaš, N., Marinčić, S., Benček, Đ.: *Osnovna geološka karta 1:100 000*, Tumač za list Ploče, K 33-35 SFRJ, Geološki zavod, Zagreb, Savezni geološki zavod Beograd, 1979.